# 日本国特許庁 JAPAN PATENT OFFICE

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出 願 年 月 日 Date of Application:

2003年 1月14日

出 願 番 号 Application Number:

特願2003-005234

[ST. 10/C]:

[ J P 2 0 0 3 - 0 0 5 2 3 4 ]

出 願 人 Applicant(s):

株式会社日立製作所

2003年 8月26日

特許庁長官 Commissioner, Japan Patent Office





【書類名】

特許願

【整理番号】

H02018281A

【あて先】

特許庁長官

【国際特許分類】

G06F 13/00

【発明者】

【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日

立製作所システム開発研究所内

【氏名】

田中 淳

【発明者】

【住所又は居所】

神奈川県川崎市麻生区王禅寺1099番地 株式会社日

立製作所システム開発研究所内

【氏名】

橋本 顕義

【発明者】

【住所又は居所】

神奈川県小田原市中里322番地2号 株式会社日立製

作所RAIDシステム事業部内

【氏名】

平児 典夫

【特許出願人】

【識別番号】

000005108

【氏名又は名称】

株式会社 日立製作所

【代理人】

【識別番号】

100075096

【弁理士】

【氏名又は名称】 作田 康夫

【電話番号】

03-3212-1111

【手数料の表示】

【予納台帳番号】

013088

【納付金額】

21,000円

【提出物件の目録】

【物件名】

明細書 1

【物件名】

図面 1

【物件名】

要約書 1

【プルーフの要否】

要

#### 【書類名】

明細書

【発明の名称】 SAN/NAS統合型ストレージ装置

### 【特許請求の範囲】

### 【請求項1】

データを記憶する複数のディスクと、

ホストコンピュータからのI/O命令を受信し、上記I/O命令に従って上記ディスクを制御する複数の制御装置と、

前記複数の制御手段を結合する相互結合網とを有し、

上記制御装置の1つは、ホストコンピュータとのインタフェースとして、ブロックインタフェースを持ち、

上記制御装置の別の1つはホストコンピュータとのインタフェースとして、ファイルインタフェースを持つことを特徴とするSAN/NAS統合型ストレージ装置。

## 【請求項2】

上記ブロックインタフェースを持つ制御装置は、

上記ホストコンピュータと通信をするチャネルアダプタと、

上記ディスクを制御するディスクアダプタとを有する請求項1記載のSAN/NAS 統合型ストレージ装置。

### 【請求項3】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、

上記ホストコンピュータから受信したファイルレベルのコマンド、データをブロックインタフェースに変換するファイルシステムと、

上記相互結合網とのインターフェィスを持つチャネルアダプタ部と、

上記ディスクを制御するディスクアダプタとを有する請求項1記載のSAN/NAS 統合型ストレージ装置。

#### 【請求項4】

上記相互結合網に接続され、上記複数の制御装置で共用される制御メモリを有する請求項1記載のSAN/NAS統合型ストレージ装置。

#### 【請求項5】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、

上記ホストコンピュータから受信したファイルレベルのコマンド、データをブロックインタフェースに変換するファイルシステムと、

上記相互結合網と上記のインターフェィスを持つチャネルアダプタ部を、

単一のボード上に実装することを特徴とする請求項1記載のSAN/NAS統合型ストレージ装置。

### 【請求項6】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、

上記ホストコンピュータから受信したファイルレベルのコマンド、データをブロックインタフェースに変換するファイルシステムと、

上記ファイルシステムから発行されたブロックレベルのコマンド、データを受信するチャネルアダプタ部と、

上記ディスクを制御するディスクアダプタとを有する請求項1記載のSAN/NAS 統合型ストレージ装置。

#### 【請求項7】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、

ブロックレベルの入出力命令、入出力データを受信するチャネルアダプタ部間に通信パスを複数持ち、コマンド、データを別々のパスにて送受信することを特徴とする請求項1記載のSAN/NAS統合型ストレージ装置。

#### 【請求項8】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、ブロックレベルの入出力命令、入出力データを受信するチャネルアダプタ部間にある物理的な通信パスを、仮想的に複数の独立したパスが存在するように制御し、コマンド、データを別々のパスにて送受信することを特徴とする請求項1記載のSAN/NAS統合型ストレージ装置。

### 【請求項9】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、ブロックレベルの入出力命令、入出力データを受信するチャネルアダプタ部間にある物理的な通信パスを、仮想的に複数の独立したパスが存在するように制御し、コマンド内部にファイルシステムに固有な情報を挿入し、コマンドとデータを別々のパスにて送受信することを特徴とする請求項1記載のSAN/NAS統合型ストレージ装置。

### 【請求項10】

上記ファイルインタフェースを持つ制御装置は、

上記ホストコンピュータとの通信をするファイルサーバ部と、ブロックレベルの入出力命令、入出力データを受信するチャネルアダプタ部間に障害情報用の通信パスを持ち、コマンド、データの通信パスとは独立に障害情報を制御メモリへ送信することを特徴とする請求項1記載のSAN/NAS統合型ストレージ装置。

### 【請求項11】

データを記憶するディスクと、

第1のホストコンピュータに接続される第1のネットワークに直結される第1 のアダプタと、

上記ディスクに直結される第2のアダプタと、

上記第1のアダプタ、第2のアダプタに直結してこれらを結合する第2のネットワークとを有し、

上記第1のアダプタは、上記第1のネットワークを介してホストコンピュータ から受信した第1のプロトコルに従う情報を第2のプロトコルに従う情報に変換し、上記第2のネットワークを介して上記第2のアダプタに転送するストレージ 装置。

#### 【請求項12】

第2のホストコンピュータと第3のネットワークを介して接続される第3のアダプタと、

上記ディスク、第1のアダプタ、第2のアダプタ、第3のアダプタを結合する 第2のネットワークとを有し、 上記第1のネットワーク上の通信プロトコルが第1のプロトコルであり、上記第2及び第3のネットワーク上の通信プロトコルが第2のプロトコルである請求項11記載のストレージ装置。

### 【請求項13】

上記第1のプロトコルは「E thernet II」「IEEE802.3」および「IEEE 802.2」のいずれかの規格に基づくプロトコルである請求項1 2 記載のストレージ装置。

### 【請求項14】

上記第1のアダプタは、

上記ホストコンピュータとファイルレベルのコマンド、データの送受信を行う ファイルサーバ部と、

上記第2のアダプタとブロックレベルのコマンド、データの送受信を行うチャネルアダプタ部と、

を有し、

それらが単一のボード上または単一の筐体内に構成されている請求項12記載のストレージ装置。

### 【請求項15】

上記ファイルサーバ部は、

該ファイルサーバ部を制御するサーバプロセッサと、

上記第1のネットワークから来るデータ、コマンドの制御を行うLANコントローラと、

上記サーバプロセッサと上記LANコントローラを接続する第1の内部バスと、 を有し、データ、コマンドの変換処理を行い上記チャネルアダプタ部へ送り、 上記チャネルアダプタ部は、

上記変換処理を行ったデータ、コマンドを上記第2のネットワークへ送付する 請求項14記載のストレージ装置。

#### 【請求項16】

上記ファイルサーバ部と上記チャネルアダプタ部の間に、

上記データを送受信するネットワークデータパスと、

上記コマンドを送受信する制御データパスと、

を物理的または論理的に独立に有し、該ネットワークデータパスおよび制御データパスは、上記第1の内部バスに接続されている請求項15記載のストレージ装置。

### 【請求項17】

上記チャネルアダプタ部は、

上記第2のネットワークとの上記データの送受信を制御するネットワークデー タコントローラと、

上記第2のネットワークとの上記コマンドの送受信を制御する制御データコントローラと、

上記ネットワークデータコントローラと上記制御データコントローラを接続する第2の内部バスと、

を有し、該第2の内部バスは、上記ネットワークデータパスおよび制御データパスに接続されている請求項16記載のストレージ装置。

### 【請求項18】

上記ファイルサーバ部は、

上記サーバプロセッサと上記第1の内部バスとの間の上記データ、コマンドの 送受信、障害情報の制御を行うホストコントローラを有し、

上記チャネルアダプタ部は、

該チャネルアダプタ部を制御するチャネルプロセッサを有し、

上記ファイルサーバ部と上記チャネルアダプタ部の間に、上記サーバプロセッサおよびホストコントローラの少なくとも一つと、上記チャネルアダプタ部を接続し、上記第1の内部バスを介さずに障害情報の送受信を行う管理バスを有する請求項17記載のストレージ装置。

#### 【請求項19】

上記管理バスは上記チャネルアダプタ部内の制御データコントローラに接続されており、障害のため上記第1の内部バスが使えない場合でも、上記サーバプロセッサまたは上記ホストコントローラの障害情報を上記チャネルアダプタ部に転送する請求項18記載のストレージ装置。

### 【請求項20】

上記チャネルプロセッサと接続される管理ネットワークと、

上記管理ネットワークと接続される管理プロセッサを有し、

上記チャネルプロセッサは制御データコントローラと接続されて上記障害情報 を収集し、該障害情報を上記管理プロセッサに転送し、

上記管理プロセッサは受信した情報に基づいて、上記チャネルプロセッサに指示を行う請求項19記載のストレージ装置。

### 【請求項21】

上記第2のネットワークに接続された制御メモリを有し、

上記管理プロセッサは、上記制御メモリにある障害情報を元に障害が発生したファイルインタフェースを持つ第1のアダプタの動作を停止し、他の正常なファイルインタフェースを持つ第1のアダプタにその制御手段の動作を代替させることを特徴とする請求項21記載のストレージ装置。

### 【請求項22】

上記管理プロセッサは、上記チャネルプロセッサから入手した障害情報と上記制御メモリ内にある障害情報を比較し、障害が発生したファイルインタフェースを持つ制御手段の特定と、障害処理方法の選択を行うことを特徴とする請求項21記載のストレージ装置。

#### 【請求項23】

上記第1のアダプタは、上記ファイルサーバ部と上記チャネルアダプタ部の状態を上記管理プロセッサに送信し、上記状態を基に管理用コマンドを受信することを特徴とする請求項21記載のストレージ装置。

#### 【請求項24】

上記管理プロセッサは管理用ディスプレイと接続され、上記障害情報に基づいた情報を、管理用ディスプレイ上に表示することを特徴とする請求項20記載のストレージ装置。

#### 【請求項25】

「Ethernet II」「IEEE802.3」および「IEEE802.2」のいずれかの規格(「外部プロトコル」という)に基づくプロトコルによりホストコンピュータ

とコマンドおよびデータを送受信し、上記外部プロトコル以外のプロトコル(「 内部プロトコル」という)によって記録ディスクにアクセスするディスク制御装 置であって、

該制御装置は単一のボード上または筐体内にファイルサーバ部とチャネルアダ プタ部を有し、

上記ファイルサーバ部は、

該ファイルサーバ部を制御し、上記外部プロトコルから内部プロトコルへデータ、コマンドの変換処理するサーバプロセッサと、

上記外部プロトコルによるデータ、コマンドの通信制御を行うLANコントローラと、

上記サーバプロセッサと上記LANコントローラを接続する第1の内部バスと、

上記サーバプロセッサと上記第1の内部バスとの間にあって、上記データ、コマンドの送受信、および、障害情報の制御を行うホストコントローラを有し、

上記チャネルアダプタ部は、

上記記録ディスクとの間で上記データの送受信を制御するネットワークデータ コントローラと、

上記記録ディスクとの間で上記コマンドの送受信を制御する制御データコントローラと、

上記チャネルアダプタ部を制御するチャネルプロセッサと、

上記ネットワークデータコントローラと上記制御データコントローラを接続する第2の内部バスとを有し、

上記ファイルサーバ部と上記チャネルアダプタ部の間に、

上記第1及び第2の内部バスに接続され、上記内部プロトコル基づいたデータ を送受信するネットワークデータパスと、

上記第1及び第2の内部バスに接続され、内部プロトコル基づいたコマンドを 送受信する制御データパスとを物理的または論理的に独立に有し、

上記第1及び第2の内部バスを介さずに障害情報の送受信を行う管理バスとを 有するディスク制御装置。

#### 【発明の詳細な説明】

### $[0\ 0\ 0\ 1]$

### 【発明の属する技術分野】

本発明は、ファイルシステム及びストレージシステムを統合化した装置および その管理方法に関し、特にファイルシステムからI/0コマンド、障害処理を高速 に処理する技術に関する。

[0002]

【従来の技術】

【特許文献1】

特開2000-99281号公報

【特許文献2】

特開2002-14878号公報

【非特許文献1】

米国特許公開公報2002/0116593

従来、ホストコンピュータと接続されて用いられるストレージ装置として、特開2000-99281号公報に開示されたものがある。これは、ストレージ装置内のデータ転送、制御を高速化するために、ホストコンピュータと接続されるチャネルアダプタ、ディスク装置と接続されるディスクアダプタ、ディスクキャッシュ、制御メモリ間を相互結合網で接続する構成をとる。

[0003]

また、イーサネット(登録商標)用のポートしかないユーザでも接続できるように、ストレージ装置内のファイルサーバとホストコンピュータとをイーサネットで接続し、ファイルサーバとチャネルアダプタとの間はファイバーチャネルポートのブロックインタフェースで接続したストレージ装置が、例えば米国特許出願2002/0116593に開示されている。

[0004]

なお、専用のネットワークによって、例えばファイバーチャネルプロトコルによりサーバ、ストレージ間の通信を行う方式を、一般にSAN(Storage Area Network)という。また、LANに直接接続し、例えばイーサネットを介してTCP/IPプロトコルや「Ethernet は登録商標)「IEEE802.3」「IEEE8

02.2」等の規格に基づくプロトコルで通信を行う方式を一般にNAS(Network Area Storage)という。

一方、ファイルサーバから直接ストレージ装置に障害情報を伝えるパスを持つ 計算機システムとして、例えば特開2002-14878号公報に開示されている方法があ る。

### [0005]

### 【発明が解決しようとする課題】

本発明の課題は、SAN/NASを統合・集約化した新しいシステムを提供することにある。

### [0006]

図3は本発明の比較例として創作したシステム構成図である。このシステムは 、相互結合網を適用し、かつ、ファイルシステム及びストレージシステムを統合 ・集約化したSAN/NAS統合型ストレージシステムである。

### [0007]

一般に、ユーザ、アプリケーションがデータのアクセスを行うためには、図3にあるようにホストコンピュータ(300)、ファイルサーバ(310)、ストレージ装置(340)を用いる必要がある。その場合ユーザ、アプリケーションはホストコンピュータ(300)に存在し、そこからネットワークやイーサネットポート(305)を経由して、ファイルを管理するファイルサーバ(310)へデータのアクセス要求を出す。ファイルサーバ(310)はユーザ、アプリケーションの把握しているデータ(ファイル)の管理を行い、ディスク(160,161)に対してデータ(ブロック)のリード、ライト要求を出す。ファイルサーバ(310)はこのときファイル情報からブロック情報への変換を行う。ディスク(160,161)はファイルサーバ(310)からのコマンドに従ってデータの格納、読み出しを行う。

このようなストレージ装置(3 4 0)おいて、ディスク(1 6 0, 1 6 1)の容量の増加、インターフェィス性能やプロセッサ性能の向上、LSIやボードの実装密度増加に伴い、ハードの集約化を行うことが進められている。それに伴いチャネルアダプタ数、ディスク数は増加し、ストレージ装置内のデータ転送、制御を

高速化するためにチャネルアダプタ(110,310)、ディスクアダプタ(140、141)、ディスクキャッシュ(132)、制御メモリ間(131)を相互結合網(130)で接続する構成をとることが有利である。相互結合網を持つストレージ装置として、前述の特開2000-99281号公報に開示されている方法がある。

### [0008]

一方管理コストの削減の要求から、複数のユーザデータのストレージ装置(340)への集約化が進んでいる。しかしすべてのユーザがファイバーチャネルに代表されるブロックインターフェィスを持っているわけではなく、多くのユーザはイーサネットに代表されるIPインターフェィスしか持っていない場合が多い。また離れた地域よりストレージ装置(340)に接続する場合、ファイバーチャネルを用いるとコストが増大する問題がある。よって図3に示すように、ストレージ装置(340)の集約化を進めるにあたり、ストレージ装置(340)内にファイルサーバを内蔵し、イーサネットポート(305)等のIPインターフェィスしかないユーザでも接続できるようにストレージ装置内(340)にファイルサーバ(310)を置き、チャネルアダプタ(330)との間はファイバーチャネルポート(320)等のブロックインタフェースで接続したストレージ装置(340)の要望が高くなっている。

#### [0009]

このようにIPインターフェィスを持つNASとして、例えば米国特許出願2002/01 16593に開示されている方法がある。当該特許出願に開示されているストレージ 装置は、ユーザに対してはIPインターフェィスを制御するファイルサーバを持ち、ストレージ装置とは相互スイッチを介したファイバーチャネルで接続される構成をとっている。この方法によれば、ファイルサーバ処理とストレージ処理を別々に行うので、高性能化が図れる。

#### $[0\ 0\ 1\ 0]$

一方、ストレージ装置の規模が増大し、NASが一般になってきた場合、システム全体の高信頼性を保つためにファイルサーバ (3 1 5) とストレージ装置 (3 4 0) の間の障害処理連携が必要になってくる。特にファイルサーバ側 (3 1 5

)の障害時にその情報がストレージ装置(3 4 0)側に直接伝わらなければ、障害部位の切り離し、他の部位へのフェイルオーバーなどに時間がかかることになり、信頼性、性能ともに低下する。そのために通常のデータが通るパスとは別に障害情報を別のパスを使って障害情報を送信する方式が検討されている。このような、ファイルサーバから直接ストレージ装置に障害情報を伝えるパスを持つ計算機システムとして、例えば特開2002-14878号公報に開示されている方法がある。当該公報に開示されている計算機システムは、ファイルサーバ側のプロセッサが制御するホストバスを使わず、ストレージ装置に障害情報を連絡するパスを別に持つ構成を採用している。この方法によれば、ファイルサーバ側の障害をプロセッサの状態によらず直接知ることができ、システムの高信頼化を保つことができる。

#### [0011]

しかし、上記した特開2000-99281号公報に開示されているストレージ装置では、ホストコンピュータとのインターフェィスはIPインターフェィスを含んでいない。従って、ファイルサーバを持っていないユーザはこのストレージ装置に接続ができない。そのため、このストレージ装置に接続するために新たにファイサーバを用意する必要がある。図3は新たにファイルサーバ(310)を備えた例であるが、この比較例には管理コスト、設置面積が増大する問題がある。

#### $[0\ 0\ 1\ 2]$

また米国特許出願2002/0116593に開示されているNAS装置については、装置内にNASを持つので、ファイルサーバとストレージ装置が連結されているが、1回のデータやコマンドを転送するために使う接続パスはファイバーチャネルケーブル1本であり、負荷が高い場合性能低下を招く可能性が高い。さらにファイバーチャネルケーブルのみで接続されているため、ファイルサーバに障害が発生した場合、ストレージ装置にその障害情報を伝えることができない。よってフェィルオーバーを完了するために多くの時間がかかる可能性が高い。つまり、このNAS装置では性能低下と信頼性低下の問題がある。

### [0013]

一方、障害処理に関して特開2002-14878号公報に開示されている計算機システ

ムは、直接ディスク制御装置側(本公知例では I / O プロセッサと記載)にファイルサーバ(本公知例では主プロセッサと記載)の障害情報の送信ができるが、その情報を障害処理に用いるためには、ファイルサーバの設定情報を変更しIPネットワークを通して外部の管理サーバに伝えられた後になるため、IPネットワークの負荷が高い場合などには相手は的確に障害情報を取得できないか、障害情報の伝達に時間がかかる問題がある。

以上の課題により、本発明の目的は、ストレージ装置内にファイルサーバのイン ターフェィスを持つシステムおよびその方法を提供することである。

### [0014]

本発明の他の目的は、ファイルサーバとストレージ装置間において、コマンドとデータを並列に処理するシステムおよびその方法を提供することである。

### [0015]

本発明のさらに他の目的は、ファイルサーバの障害情報を通常のコマンド、データと別にストレージ装置に転送し、その情報をストレージ装置全体で共有するシステムおよびその方法を提供することである。

#### $[0\ 0\ 1\ 6\ ]$

本発明のさらに他の目的は、ストレージ装置で共有した障害情報を使って障害 の発生したファイルサーバのフェィルオーバーを行うシステムおよびその方法を 提供することである。

### [0017]

#### 【課題を解決するための手段】

上記課題を解決するために、本発明の一態様であるストレージ装置では、データを記憶するディスクと、第1のホストコンピュータに接続される第1のネットワークに直結される第1のアダプタと、ディスクに直結される第2のアダプタと、第1のアダプタ、第2のアダプタに直結してこれらを結合する第2のネットワークとを有し、第1のアダプタは、第1のネットワークを介してホストコンピュータから受信したのプロトコルに従う情報を第2のプロトコルに従う情報に変換し、第2のネットワークを介して第2のアダプタに転送する。本発明では、ホストコンピュータとアダプタ間を、例えばPCIインタフェースなどの内部バスを

用いて、冗長なプロトコル変換を行わない高速インタフェースで接続することができる。特に、本発明では、ファイルサーバと、ストレージ装置のチャネルアダプタとを、第1のアダプタとして同一基板上に置き、それらの間を高速なインターフェィスで接続できるようにする。

### [0018]

第1のプロトコルは、例えば「Ethernet II」「IEEE802.3」および「IEEE802.2」のいずれかの規格に基づく、いわゆるイーサネットプロトコルであり、種々のホストコンピュータとの接続を可能とする。第2のプロトコルは例えばファイバーチャネルであり、専用の高速チャネルを実現することができる。本発明は、第1のアダプタのみによりこの両者を結合することが可能である。従って、スペースファクターや保守に優れる。

### [0019]

ファイルサーバ部は、ファイルサーバ部を制御するサーバプロセッサと、第1のネットワークから来るデータ、コマンドの制御を行うLANコントローラと、サーバプロセッサと上記LANコントローラを接続する第1の内部バスとを有する。たとえば、サーバプロセッサはデータ、コマンドの変換処理を行い、第2のプロトコルによりチャネルアダプタ部へ送る。チャネルアダプタ部は、変換処理後のデータ、コマンドを第2のネットワークへ送付する。

#### [0020]

このように、ファイルサーバ部とチャネルアダプタ部を一体構成としたことにより、両者の間に、データを送受信するネットワークデータパスと、コマンドを送受信する制御データパスとを物理的または論理的に独立に備えることとすることも容易にできる。すなわち、ファイルサーバとストレージ装置の間に複数の独立したパスを設け、I/O処理の中でデータとコマンドを別のパスで処理できるようにする。

### [0021]

さらに、ファイルサーバ部は、サーバプロセッサと第1の内部バスとの間のデータ、コマンドの送受信、障害情報の制御を行うホストコントローラを有してもよい。また、チャネルアダプタ部は、チャネルアダプタ部を制御するチャネルプ

ロセッサを有してもよい。ファイルサーバ部とチャネルアダプタ部の間には、第 1 の内部バスを介さずに障害情報の送受信を行う管理バス備えることが望ましい。この管理バスは、例えばサーバプロセッサあるいはホストコントローラと、チャネルアダプタ部内の制御データコントローラを直結する。障害のため第1の内部バスが使えない場合でも、サーバプロセッサまたは上記ホストコントローラの障害情報を上記チャネルアダプタ部に転送することができる。このように、ファイルサーバの障害処理情報をI/0処理と異なるパスを使ってストレージ装置に転送できるようにする。また上記障害処理情報をストレージシステムで共用できるようにメモリに保存し、フェィルオーバーを行う他のストレージ装置、ファイルサーバから参照できるようにする。

#### [0022]

本発明の他の観点は上述の新規な第1のアダプタであり、これは、例えば「Ethernet II」「IEEE802.3」および「IEEE802.2」のいずれかの規格(「外部プロトコル」という)に基づくプロトコルによりホストコンピュータとコマンドおよびデータを送受信し、外部プロトコル以外のプロトコル(「内部プロトコル」という)によって記録ディスクにアクセスするディスク制御装置であって、制御装置は筐体内または好ましくは単一のボード上にファイルサーバ部とチャネルアダプタ部を有する。

#### [0023]

ファイルサーバ部は、ファイルサーバ部を制御し、外部プロトコルから内部プロトコルへデータ、コマンドの変換処理するサーバプロセッサと、外部プロトコルによるデータ、コマンドの通信制御を行うLANコントローラと、サーバプロセッサと上記LANコントローラを接続する第1の内部バスと、サーバプロセッサと第1の内部バスとの間にあって、データ、コマンドの送受信、および、障害情報の制御を行うホストコントローラを有する。

#### [0024]

チャネルアダプタ部は、記録ディスクとの間でデータの送受信を制御するネットワークデータコントローラと、記録ディスクとの間でコマンドの送受信を制御する制御データコントローラと、チャネルアダプタ部を制御するチャネルプロセ

ッサと、ネットワークデータコントローラと制御データコントローラを接続する 第2の内部バスとを有し、ファイルサーバ部と上記チャネルアダプタ部の間に、 第1及び第2の内部バスに接続され、内部プロトコルに基づいてデータを送受信 するネットワークデータパスと、第1及び第2の内部バスに接続され、内部プロトコルに基づいてコマンドを送受信する制御データパスとを物理的または論理的 に独立に有し、第1及び第2の内部バスを介さずに障害情報の送受信を行う管理 バスとを有する。

### [0025]

さらに他の本発明の態様であるストレージ装置は、データを記憶する複数のディスクと、ホストコンピュータからのI/O命令を受信し、I/O命令に従って上記ディスクを制御する複数の制御装置と、複数の制御手段を結合する相互結合網とを有し、制御装置の1つは、ホストコンピュータとのインタフェースとして、ブロックインタフェースを持ち、制御装置の別の1つはホストコンピュータとのインタフェースとして、ファイルインタフェースを持つことを特徴とする。ここで、ファイルインタフェース(ファイルシステムインタフェース)とは、ファイル名を元にしてデータの送受信を行うインタフェースをいう。ブロックインタフェース(ブロックデバイスインタフェース)とは、SCSIに代表されるようなデバイス識別子、先頭ブロックアドレス、ブロック数などを元にデータの送受信を行うインタフェースをいい、これは、ディスク内のデータ位置を示すブロックアドレスを指定してデータにアクセスを行う。このように、取り扱うプロトコルの異なるインタフェースを統合したストレージ装置を提供する者である。

[0026]

#### 【発明の実施の形態】

以下、本発明の実施例を図1を参照して説明する。

[0027]

図1は本発明の第1の実施例の構成図である。

[0028]

図1において、100はユーザ、アプリケーションのデータを保存するストレージ装置である。本発明のストレージ装置(100)は、ホストコンピュータ(

101、300)に適合するインターフェィスを持つ。ファイバーチャネルイン ターフェィスを持つホストコンピュータ(300)に対しては、複数のファイバ ーチャネルポートからなるファイバーチャネルインターフェィス (103) で接 続する。IPインターフェィスを持つホストコンピュータに対しては、複数のイー サネットポートからなるイーサネットインターフェィス(104、105)で接 続する。ストレージ装置(100)の内部は、ホストコンピュータ(300)の ファイバーチャネルインターフェィス(103)を接続しデータ、コマンド処理 を行う、チャネルアダプタ(110)と、ホストコンピュータ(101)のイー サネットインターフェィス(104)を外部ネットワーク(102)経由で接続 しファイルを含むデータ、コマンドの処理を行う、ファイルサーバボード(11 2、115) を持つ。ファイルサーバボード(112、115) は自らOSを持ち 、ホストコンピュータ(101)からのIPプロトコルの処理、ファイルレベル要 求のブロックレベル要求への変換を行うファイルサーバ部(113)とブロック レベル要求を処理するチャネルアダプタ部(114)からなる。このファイルサ ーバ部とチャネルアダプタ部(114)は同一ボード上に配置され、後で説明す るように複数の高速なインターフェィスで接続されている。またストレージ装置 (100)は、データの一時的保存とデータのリード、ライトの高速化を行うデ ィスクキャッシュ(132)とストレージ内のデータの整合性を維持、装置内の 状態を保存、共用するための制御メモリ(133)を持つ。さらにストレージ装 置(100)は最終的にデータを保存するディスク(160、161)を制御す るディスクアダプタ(140、142)を持つ。チャネルアダプタ(110)、 ファイルサーバボード(112)、ディスクキャッシュ(132)、制御メモリ (133) ディスクアダプタ (140、142) は相互結合網 (130) とのイ ンターフェィスを持ち、お互いに結合されている。相互結合網(130)はスイ ッチ等で構成されており、外部ネットワーク(102)に比べ高速、かつ高信頼 なネットワークになっている。以上の構成により本発明のストレージ装置は、同 一装置で複数のインターフェィスを持つので、図3に示したように余計なファイ ルサーバを用意する必要がなく、装置コストを下げることが可能となる。次にフ ァイルサーバボード(112、115)の詳細について説明する。

[0029]

図2は本発明におけるファイルサーバ部とチャネルアダプタ部を統合した、ファイルサーバボードの構成図である。

[0030]

図2において、200は外部ネットワーク(102)を通して、ホストコンピ ュータとファイルレベルのコマンド、データの送受信を行い、相互結合網(13 0)を通して、ディスクキャッシュ(132)、制御メモリ(133)ディスク アダプタ(140、142)とブロックレベルのコマンド、データの送受信を行 う、ファイルサーバボード(112、115)の基本構成を示している。なお図 2では説明を容易にするため、外部ネットワーク(102)、相互結合網(13 0)とのインターフェィス数は1個に限定してあるが、それらが複数存在する場 合も当然本特許の範囲にある。201はファイルサーバ部であり、外部ネットワ ーク(102)からのコマンド、データを受け取り、自ファイルシステム内の処 理を行った後、ブロックレベルのデータ、コマンドの変換処理を行いチャネルア ダプタ部(202)へ送る。210はサーバプロセッサであり、ファイルサーバ 部(201)の全体を制御する。211はホストコントローラであり、サーバプ ロセッサ(210)と周辺のメモリ、内部バス(214)のデータ、コマンド、 割り込み信号の送受信、障害情報の制御を行う。212はLANコントローラであ り、外部ネットワーク(102)から来るデータ、コマンドの制御を行う。21 3はイーサネットであり、外部ネットワーク(102)とファイルサーバボード (200)を接続し、IPプロトコルに準拠したデータ、コマンドの伝送を行う。 214は内部バスであり、ホストコントローラ(211)、LANコントローラ( 212)、チャネルアダプタ部(202)を接続し、データ、コマンドの送受信 を行う。内部バス(214)以外に、サーバプロセッサ(210)、ホストコン トローラ(211)は、障害情報の送受信を独立に行うパスとして、管理バス( 230)を持つ。管理バス(230)はチャネルアダプタ部(202)内の制御 データコントローラ(221)に接続されており、障害のため内部バス(214 )使えない場合でも、サーバプロセッサ(210)、ホストコントローラ(21 1)の障害情報をチャネルアダプタ部(202)に転送する。202はチャネル

アダプタ部であり、ファイルサーバ部(201)から送られた、ブロックレベル のデータ、コマンドを受け取り、内容に応じて相互結合網(130)を通して適 当なディスクキャッシュ(132)、制御メモリ(133)、ディスクアダプタ (140、142)に送信する。220はチャネルプロセッサであり、上記チャ ネルアダプタ部(202)の全体を制御する。221は制御データコントローラ であり、ストレージ装置(100)全体を制御するために必要なデータの送受信 の制御、サーバプロセッサ(210)、ホストコントローラ(211)からの障 害情報の送受信の制御を行う。222は制御メモリ(133)用の相互結合網( 130)であり、制御データコントローラからの制御データを制御メモリ(13 3)、ディスクアダプタ(140、142)、他のチャネルアダプタ(110) 、ファイルサーバボード(113)へ転送する。223はネットワークデータコ ントローラであり、ユーザまたはアプリケーションのデータの送受信を制御する 。224はユーザ、アプリケーションデータ転送用の相互結合網(130)であ り、ネットワークデータコントローラ(223)からのデータをディスクキャッ シュ(132)、ディスクアダプタ(140、142)に転送する。231は制 御データパスであり、コマンドやストレージ装置(100)全体を制御するため に必要な情報をファイルサーバ部(201)とチャネルアダプタ部(202)間 で送受信する。232はネットワークデータパスであり、ユーザまたはアプリケ ーションのデータやデータ転送に必要なパラメータ等をファイルサーバ部(20 1)とチャネルアダプタ部(202)間で送受信する。250は管理ネットワー クであり、チャネルプロセッサ(220)で収集した障害情報、構成情報を管理 プロセッサ(255)に転送するために利用する。管理プロセッサ(255)は 受信した情報より、障害処理、構成変更等を判断し、必要であればストレージ装 置(100)に指示を行う。また管理プロセッサ(255)は各ボードの情報を 管理ディスプレイ(260)に一元的に表示することが可能である。たとえば2 61のような管理表を表示することが可能であり、ボード# (265)毎にファ イルサーバ部(266)、チャネルアダプタ部(267)の状態を表示すること が可能となる。240はファイルサーバボード(200)の電源でありここから 、ファイルサーバ部(201)、チャネルアダプタ部(202)に対して電源を

供給する。以上に述べた構成によって、同一ボード上にファイルサーバとストレ ージ装置のインターフェィスをまとめることが可能となり、装置の設置面積が削 減する。またファイルサーバとストレージ装置を同一管理プロセッサ(255) 、管理ディスプレイ(260)上で管理することも可能となり、管理コストが削 減する。さらにファイルサーバ部(201)とチャネルアダプタ部(202)間 のデータ、コマンド転送に関して、制御データパス(231)とネットワークデ ータパス(232)の2種類の独立したパスを設けることにより、コマンド、パ ラメータなどの比較的短いデータと、ユーザ、アプリケーションデータなどの比 較的長いデータを分離して処理することにより、データ転送性能を上げることが 可能になる。またコマンド等をまとめて転送することもでき、処理効率を上げる ことが可能となる。さらにコマンドとデータを分離することにより、コマンドの フォーマットを標準仕様から変更できるので装置特有な情報、パラメータをチャ ネルアダプタに直接伝えることも可能となり、ディスクキャッシュ(132)内 の常駐データの選別などが可能となる。この2種類の独立したパスは、物理的に 分離した2本のパスで構成する場合と、以下に述べるファイルサーバボード (1 12)のハード構成図のように物理的には1本のパスにて、論理的に2本のパス があるように制御を行う方式のどちらを使っても実装可能であるがそれらが本特 許の範囲にあることは明らかである。また図2ではファイルサーバボード(11 2)上にサーバプロセッサ(210)、チャネルプロセッサ(220)の2種類 のプロセッサが稼動している例を挙げたが、この形態以外にサーバプロセッサ( 2 1 0 ) のみでファイルサーバボード (1 1 2 ) 上の部品をすべて制御する方式 も実装可能であり、それも本特許の範囲であることは明らかである。

#### [0031]

図4は本発明の実施例1におけるファイルサーバボードのハード構成図である

#### [0032]

図4においてファイルサーバ部 (400) 内のサーバプロセッサ (210) とホストコントローラ (211) の間は、ホストバス (413) で接続されている。ホストコントローラ (211) には管理バス (555) を制御する管理バスコ

ントローラ(512)とサーバプロセッサ(210)のプログラム、データ等を 格納するローカルメモリ(410)と内部バス(214、225)を接続し制御 する内部バスコントローラ(511)が接続されている。内部バスコントローラ (411)はファイルサーバ部(400)とチャネルアダプタ部(460)間を 接続するパスを制御し、論理的に複数のパスがあるように内部バス(214、2 25)を制御する。つまり図3における制御データパス(231)とネットワー クデータパス(232)を論理的に構成することが可能となる。チャネルアダプ 夕部(460)内のチャネルプロセッサ(220)はローカルバスコントローラ (470)を介してローカルバス(471)に接続されている。図4では省略さ れているが、ローカルバスにはチャネルプロセッサ(220)に必要なメモリ等 が接続されている。またローカルバスコントローラ(470)は管理ネットワー ク(250)と接続されており、必要な管理情報等を管理プロセッサ(225) に送信している。ローカルバス(471)には制御データコントローラ(221 )が接続されている。制御データコントローラ(221)には内部バス(255 )が接続されており、通常の制御データの送受信が行われる。また相互結合網( 2 2 2 )を通して制御メモリ(1 3 1)、他のチャネルプロセッサと接続されて おり、制御情報、共有情報を送受信している。さらにサーバプロセッサ(210 )、管理バスコントローラ(225)からの割り込み信号(456、457)が 直接入力される。また、内部バス(214、225)が障害等で稼動していない 場合にもサーバプロセッサの情報が入手できるように、管理バス(455)も接 続されている。制御データコントローラ(221)内部には、通常制御を行うた めの通常レジスタ(480)、エラー情報を記憶するためのエラーレジスタ(4 81)、ファイルサーバ部(400)との通信制御を行うためのドアベルレジス タ(482)、通信メモリ(483)がある。内部バス(225)には制御デー タコントローラ (221) 以外にネットワークデータコントローラ (223) が 接続されており、ユーザ、アプリケーションデータを送受信する。また、チャネ ルプロセッサ(220)がファイルサーバ部(400)の起動、停止、再起動を 制御できるように、制御データコントローラ(221)と管理バスコントローラ (225)は、電源制御手段(458)で接続されている。本実施例では、電源

制御手段(458)によってファイルサーバ部の電源を制御できるものとする。 図4の構成はあくまでもひとつの実現例であり、他の構成でも本特許の範囲にあることは自明である。次に以上のべたファイルサーバボード(200)内にある制御データパス(231)を使って送受信されるコマンドの構造例を示す。

### [0033]

図5は本発明の実施例1のコマンドデータブロックのフォーマットを示す図である。

#### [0034]

図5において、500はファイルサーバ部(400)からチャネルアダプタ部 (202)に送信されるコマンドデータブロックを示している。501はコマン ドの種別であり、通常のコマンドか特殊なコマンドなのかを区別する。502、 5 1 0 、 5 3 5 、 5 4 0 はリザーブ領域で特に意味はない。 5 0 3 はTAG種別で あり、キューに格納された場合の制御方法を指示する。504はサーバプロセッ サ#であり、このコマンドを発行したサーバプロセッサ(210)を特定する。 505はIIDであり、ユーザ領域またはシステム領域へのアクセスを区別する。 506はLUNであり、サーバプロセッサ(210)がアクセスする先の論理ユニ ットの番号である。 5 1 1 はTAG#をであり、キューの内部での識別番号を示す 。515はCDBであり、通常のSCSIで使われるフォーマットに準拠したコマンド が入る。516はCDB内のオペコードであり、リード、ライト等のコマンドを区 別する。520はイニシエータポート番号であり、外部にコマンドを送信する場 合の送信元のポートの区別を行う。525は外部デバイスWWNであり、外部にコ マンドを送信する場合の送信先WWNを示す。530は外部デバイスLUNであり、外 部にコマンドを送信する場合の送信先LUNを示す。541はアドレスエントリ数 を示し、以下に続くストレージ装置(100)へ指示するパラメータの個数を示 す。 5 4 5 、 5 6 0 はLBA 1 、LBA 2 であり、LU内での相対的なアドレスを示す。 5 5 0 、 5 6 5 はサーバプロセッサ (2 1 0) のローカルメモリ (4 1 0) 内で の物理アドレスを示し、対象とするデータの格納位置となる。555、570は ストレージ装置指示パラメータであり、ファイルサーバ部内に特有な情報をここ に置きチャネルアダプタに伝える。551、571は各パラメータに対応するデ

ータのバッファサイズまたは転送データ長を示す。ストレージ装置指示パラメータの例としては、ディスクキャッシュ(132)へのデータ常駐指示がある。これを用いることにより、ストレージ装置(100)だけでは知ることのできないユーザ、アプリケーションデータの使用頻度等をつかむことが可能となり、ストレージ装置(100)の性能向上につなげることが可能になる。以上述べた、コマンドデータブロックが、サーバプロセッサ(210)、制御データコントローラ(221)、チャネルプロセッサ(220)、ディスクキャッシュ(132)間でどのように送受信されるかについて以下に説明する。

#### [0035]

図6は、本発明の実施例1のデータアクセス時のフローチャートを示す図である。

#### [0036]

サーバプロセッサ(210)、チャネルプロセッサ(220)はコマンドを効 率よく処理するためにそれぞれコマンドキュー(CmdQueue)(602、607) 、キューの先頭を示すポインタ(CmdHead)(601、606)、次に来るコマン ドを格納すべき位置を示すポインタ(CmdNext)(603、608)を持つ。コマ ンドキュー(602、607)はリングバッファになっている。またコマンド終 了後のステータスの管理のために、ステータスキュー(StQueue)(632、6 37)、キューの先頭を示すポインタ(StHead) (631、636)、次に来るコ マンドを格納すべき位置を示すポインタ(StNext)(633、638)を持つ。ス テータスキュー(StQueue)(632、637)もリングバッファとなっている 。コマンド、データ転送時に、サーバプロセッサ(210)、チャネルプロセッ サ (220) 間でコマンドキュー (CmdQueue) (602、607) の内容を随時 確認している。両者において、 CmdHead (601、606) と、CmdNext (60 3、608)の内容は一致している必要がある。そのため、制御データコントロ ーラ(221)を通してCmdHead(606)、CmdQueue(602)、CmdNext(6 03)をそれぞれ、サーバプロセッサ(210)、チャネルプロセッサ(220 )、チャネルプロセッサ(220)に転送し、整合性をとる。同様な処理はステ ータスキュー(StQueue)(632、637)にも必要であり、サーバプロセッ

サ(210)、チャネルプロセッサ(220)間でステータスキュー(StQueue)(632、637)の内容の確認を随時行う。コマンド、データ処理を行うために、サーバプロセッサ(210)のプロセス(600)で、以下、3ステップの処理が行われる。

- (1) コマンドキュー (CmdQueue) (602) に空きがあることを確認後、コマンドを格納。
- (2) キューポインタを更新し、CmdNext (603) を見てリングバッファが 溢れないように制御。
- (3) ポーリングを開始し、ステータスキューの更新をチェック。 このプロセスに対して、チャネルプロセッサ(220)のプロセス(605)で 以下の5ステップの処理が行われる。
- (4) ポーリングにより、コマンドキュー (CmdQueue) (607) の更新をチェック。
- (5) コマンドキューCmdQueue) (607) の内容をDMA転送にて、受信。
- (6) ポーリングにより、ステータスキュー (StQueue) (637) の更新を チェック。
- (7) キューの先頭を示すポインタ(CmdHead)(606)を更新。
- (8) 各コマンドを処理。

#### [0037]

次にサーバプロセッサ(210)のプロセス(610)にてコマンド処理に必要なパラメータ(611)をDMA転送にて、制御データコントローラ(221)を通してチャネルプロセッサ(220)に転送する。また同時にサーバプロセッサ(210)のプロセス(620)にてデータをDMA転送にて、ネットワークデータコントローラ(223)を通してディスクキャッシュ(132)に転送する。プロセス(610)とプロセス(620)は、図3、4で示したように独立したパスにて処理できるので、並列に処理を進めることが可能である。データ転送処理が完了した後、チャネルプロセッサ(220)のプロセス(635)にて以下の2ステップの処理が行われる。

(9) 実行結果をステータスキュー(StQueue) (637) に格納。

ページ: 24/

- (10) ドアベルレジスタ (582) セットし割り込みを発生。 このプロセスに対して、サーバプロセッサ (210) のプロセス (630) で、 以下の3ステップの処理が行われる。
- (11) 割り込みまたはポーリングより、ステータスキュー (StQueue) (632) の更新を検知
- (12) ステータスの取り出し
- (13) キューのポインタ(StNext) (633) の更新

以上のフローチャートに示したように、コマンド、ステータス毎にキューを持つ ことが可能となり、また各々、独立のパスを用いて処理できるので、データアク セス性能を向上することが可能となる。

### [0038]

図7は、本発明の実施例1のサーバプロセッサ障害発生時のフローチャートを 示す図である。

### [0039]

図7において、700はサーバプロセッサ(210)に障害が発生し、例外処理を行う必要があることを示す。ここで、通常コマンド、データが送受信される、内部バス(214、225)と内部バスコントローラ(411)は正常に動作することが期待できない。障害情報はプロセス(810)にて例外ハンドラの処理が進み、エラー報告がプロセス(715)にて制御データコントローラ(221)のエラーレジスタ(482)に割り込み信号で記録される。その後サーバプロセッサ(210)はリセット命令を待つことになる。次に制御データコントローラ(221)はプロセス(715)でサーバプロセッサ(210)に障害が発生していることをエラー割り込みの形でチャネルプロセッサ(220)に伝える。チャネルプロセッサ(220)のプロセス(720)ではエラー割り込みを受けてエラー処理関数が起動する。その後チャネルプロセッサ(220)はサーバプロセッサ(210)を初期化するために、プロセス(715)にて制御データコントローラ(221)の通常レジスタ(483)にリセット命令を送信する。制御データコントローラ(221)は次にサーバプロセッサ(210)にリセットを割り込み信号にて送信する。リセットを受けたサーバプロセッサ(210)

のプロセス(710)は次のプロセス(725)にて再起動を行う。プロセス( 725)ではサーバプロセッサ(210)内の障害要因を収集して、プロセス( 730)にて制御データコントローラ(221)の通信メモリ(481)に格納 する。ただしこの障害要因は通常パスを通して転送されるので、正しい値である 保障はない。プロセス(725)はこれらの情報の格納が終了した後、退避完了 報告をドアベルレジスタ(482)経由でチャネルプロセッサ(220)に伝え る。その後、チャネルプロセッサ(220)は正しい障害情報を確保するために 、プロセス(750)、プロセス(715)において管理バス(455)経由で 障害情報を読み出す。具体的にはチップセットレジスタリードを行う。また同時 にプロセス(745)にて制御データコントローラ(221)の通信メモリ(4 81)に格納された障害要因も読み出す。これらの情報を読み出した後、チャネ ルプロセッサ(220)は管理プロセッサ(255)へ情報を報告し、処理指令 を受領する。次に制御メモリ(131)へ障害情報転送し、他のボードに障害処 理要求を出す。次にプロセス(755)にて内部バス(214、225)のエラ ーが発生しているかどうかをチェックする。エラーがなければ、チャネルプロセ ッサ(220)はプロセス(770)にてメモリダンプの指示をネットワークデ ータコントローラ(223)に対して行う。ネットワークデータコントローラ( 2 2 3 ) は、ローカルメモリ(4 1 0) の情報等をプロセス(7 6 5) にてDMA 転送にてメモリダンプする。もし内部バス(214、225)にエラーが発生し ていた場合、メモリダンプは行わない。次にチャネルプロセッサ(220)は外 部からの障害発生ファイルサーバボード停止要求に応じて、プロセス(790) にて制御データコントローラ(221)に対して強制停止命令を発行する。制御 データコントローラ(221)は電源制御手段(458)によって、サーバプロ セッサ(210)を強制停止させる機能を持っており、上記強制停止命令を受け て,サーバプロセッサ(210)は強制閉塞する。以上の処理では、通常のバス 以外に障害情報を送信するパスを設けているので、バスに障害があった場合でも 障害情報をチャネルプロセッサ(220)に対して送信でき、障害処理の高信頼 化を図ることが可能となる。図7では、単一ファイルサーバボード(112)内 の障害情報の通信方法を示したので、これを用いて複数ファイルサーバボード(

ページ: 26/

112) 間でのフェイルオーバーを行う方法について以下で説明する。

### [0040]

図8は、本発明の実施例1のサーバプロセッサ障害時のフェイルオーバーのフ ローチャートを示した図である。800は図7同様、サーバプロセッサ(210 )に障害が発生し、例外処理を行う必要があることを示す。障害を感知したチャ ネルプロセッサ(220)は図7で説明したサーバプロセッサ障害発生時の処理 を行う。その中で制御メモリ(131)に対して障害情報と障害処理要求を書き 込む。その後フェイルオーバー先のファイルサーバボード(115)がプロセス (810)にて障害処理を検知する。その後ファイルサーバボード(115)は 障害発生元のファイルサーバボード(112)に対して停止要求を出す。その後 停止完了の通知が来るまでプロセス(815)の待ち状態に入る。ファイルサー バボード(115)からのファイルサーバボード停止要求を受けた、ファイルサ ーバボード(112)は図7で説明したように、サーバプロセッサを停止する。 さらに、プロセス(820)で残っているI/0処理を破棄した後、制御メモリ( 131)に対してファイルサーバボード(112)の停止を書き込み、チャネル プロセッサを停止する。ファイルサーバボード(112)の停止を受けた制御メ モリ(131)はプロセス(825)にてストレージ装置(100)の構成情報 を更新し、停止をフェイルオーバー先のファイルサーバボード(115)に通知 する。停止の通知を受けた、フェイルオーバー先のファイルサーバボード(11 5)はプロセス(930)にてファイルサーバの引継ぎを行い、その結果を管理 プロセッサ(255)に通知し、フェイルオーバーを完了する。

#### $[0\ 0\ 4\ 1]$

以上述べた実施例により本特許に開示されたSAN/NAS統合型ストレージ装置を使うと、通常のI/O処理では、サーバプロセッサ(210)、チャネルプロセッサ(220)毎にコマンドキュー(CmdQueue)(602、607)、ステータスキュー(StQueue)(632、637)を持つことにより、非同期にコマンド処理、ステータス処理を進めることが可能になり、またコマンド、データを独立のパスを用いて処理することも可能になるので、I/O処理性能を向上できる。さらに、コマンド、データで独立なパスを使い、またコマンドを拡張することにより

、ファイルサーバ固有のI/0特性をストレージ装置に伝えることが可能となり、ディスクキャッシュ(132)のヒット率の向上等のストレージ装置(100)最適化が図れる。さらに同一ボード上にファイルサーバ、ディスク制御装置のチャネルアダプタがあり、同一の管理プロセッサ(255)、管理ディスプレイ(260)で管理することが可能になるので、設置面積の減少、管理コストの削減ができる。障害処理では、管理バス(455)から障害情報を送信し、ストレージ装置(100)で共有している制御メモリ(131)に書き込むことで、バスの障害にかかわらず、他のファイルサーバボードに対して早く障害情報を伝えることが可能となり、フェィルオーバーの効率を上げ、信頼性を向上できる。

#### [0042]

#### (実施例2)

図9は、本発明の実施例2のサーバプロセッサ障害時のフェイルオーバのフローチャートを示す図である。

図8では、障害発生元のファイルサーバボード(112)が自立的に障害発生を フェイルオーバー先のファイルサーバボード(115)に通知したが、障害のよ っては通知ができない場合があり、障害処理が開始できない。このようなケース を避けるため、フェイルオーバー先のファイルサーバボード(115)が積極的 に他のファイルサーバボード(112)を監視する方式が考えられる。正常な場 合、ファイルサーバボード(112)は一定時間間隔でハートビートをフェイル オーバー先のファイルサーバボード(115)に伝える。もしプロセス(900 )のように、障害が発生して一定時間内にこのハートビートが通知されない場合 、フェイルオーバー先のファイルサーバボード(115)は障害が発生と判断し 、プロセス(905)のように障害処理を開始する。障害発生元のファイルサー バボード(112)が障害情報を制御メモリ(131)に書き込んだ後、フェイ ルオーバー先のファイルサーバボード(115)は制御メモリ(131)に構成 情報を読み出し、障害が発生したことを確認し障害処理内容を確定する。その後 プロセス(905)にてファイルサーバボード(115)は障害発生元のファイ ルサーバボード(112)に対して停止要求を出す。その後の処理は図8と同様 に、その後停止完了の通知が来るまでプロセス(920)の待ち状態に入る。フ

ァイルサーバボード(115)からのファイルサーバボード停止要求を受けた、ファイルサーバボード(112)は図7で説明したように、サーバプロセッサを停止する。さらに、プロセス(925)で残っているI/O処理を破棄した後、制御メモリ(131)に対してファイルサーバボード(112)の停止を書き込み、チャネルプロセッサを停止する。ファイルサーバボード(112)の停止を受けた制御メモリ(131)はプロセス(930)にてストレージ装置(100)の構成情報を更新し、停止をフェイルオーバー先のファイルサーバボード(115)に通知する。停止の通知を受けた、フェイルオーバー先のファイルサーバボード(115)はプロセス(935)にてファイルサーバの引継ぎを行い、その結果を管理プロセッサ(255)に通知し、フェイルオーバーを完了する。

以上述べた実施例により、開示されたSAN/NAS統合型ストレージ装置を使うと、障害発生元のファイルサーバボード(1 1 2)から障害発生の送信ができない場合でも早い段階でフェイルオーバー先のファイルサーバボード(1 1 5)が障害発生の検知、確認を行うことが可能となり、フェィルオーバーの効率を上げ、信頼性を向上できる。

## [0043]

## 【発明の効果】

本発明によれば、ファイルサーバとディスク制御装置間のI/0コマンド、データの送受信を独立して行えるため、I/0処理性能が向上できるという効果がある。またアプリケーション、ファイルシステムのI/0特性情報をディスク制御装置に与えることができるため、I/0処理の最適化ができるという効果がある。また同一のボード上にファイルサーバとディスク制御装置のチャネルアダプタを実装し、統一した管理プロセッサ、管理プロセッサで管理するために、装置の設置面積の減少、管理コストの削減ができる効果がある。また、独立した経路でファイルサーバの障害情報を共有できるため、フェイルオーバーの効率化、高信頼化ができるという効果がある。

#### 【図面の簡単な説明】

#### 【図1】

本発明のSAN/NAS統合型ストレージシステムの構成図。

ページ: 29/E

#### 【図2】

本発明におけるファイルサーバ部とチャネルアダプタ部を統合した、ファイル サーバボードの構成図。

#### 【図3】

比較例のSAN/NAS統合型ストレージシステムの構成図。

### 【図4】

実施例1におけるファイルサーバボードのハード構成図。

#### 【図5】

実施例1のコマンドデータブロックのフォーマットを示す図。

#### 【図6】

実施例1のデータアクセス時のフローチャートを示す図。

### 【図7】

実施例1のサーバプロセッサ障害発生時のフローチャートを示す図。

#### 【図8】

実施例1のサーバプロセッサ障害時のフェィルオーバーのフローチャートを示す図。

#### 【図9】

実施例2のサーバプロセッサ障害時のフェィルオーバーのフローチャートを示す図。

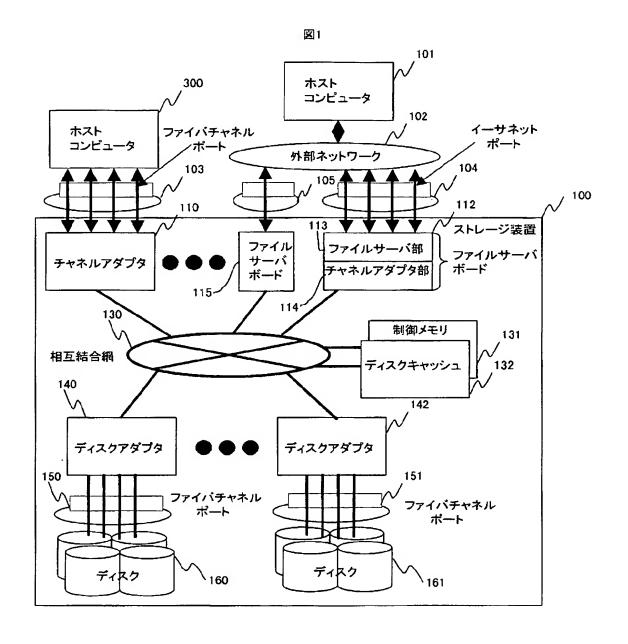
#### 【符号の説明】

100、101、150、151: ファイバチャネルインターフェィス、 102: イーサネットインターフェイス、 110: チャネルアダプタ、112: ファイルサーバボード、113: ファイルサーバ部、114: チャネルアダプタ部、 130: 相互結合網、 131: ディスクキャッシュ、 132: 制御メモリ、 140、142: ディスクアダプタ、 160, 161: ドライブ。

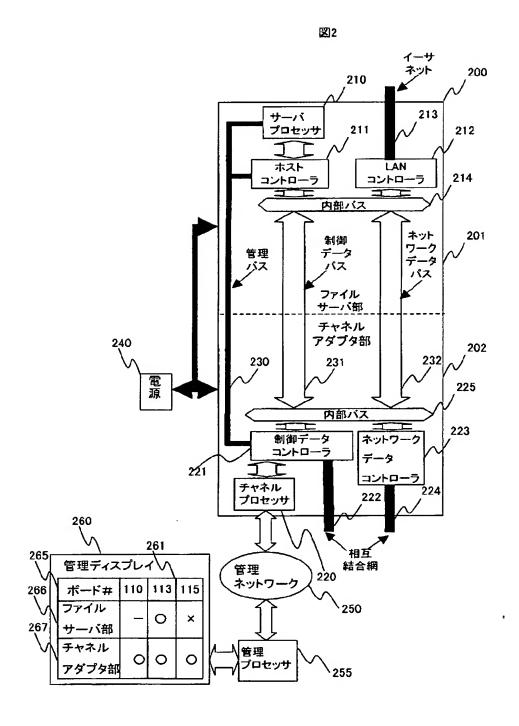
【書類名】

図面

【図1】

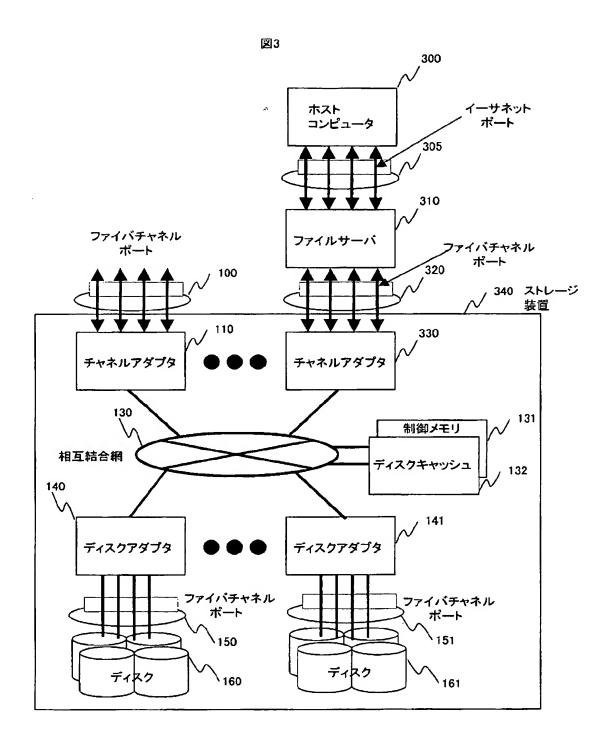


【図2】

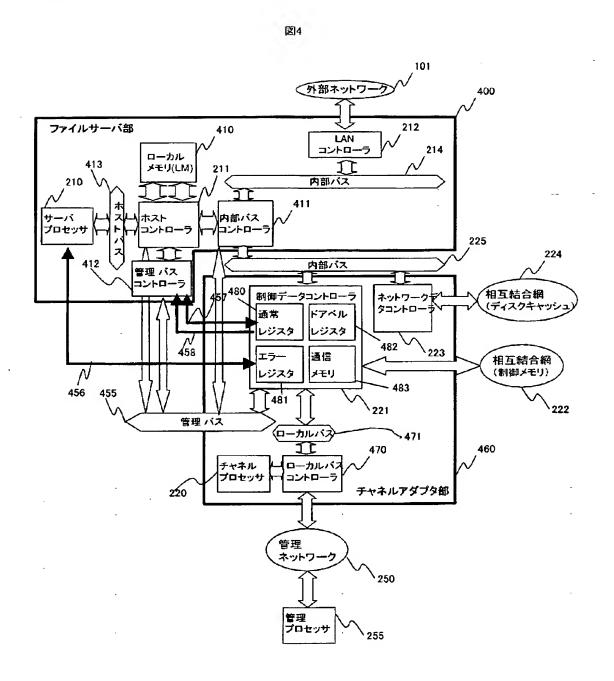


【図3】

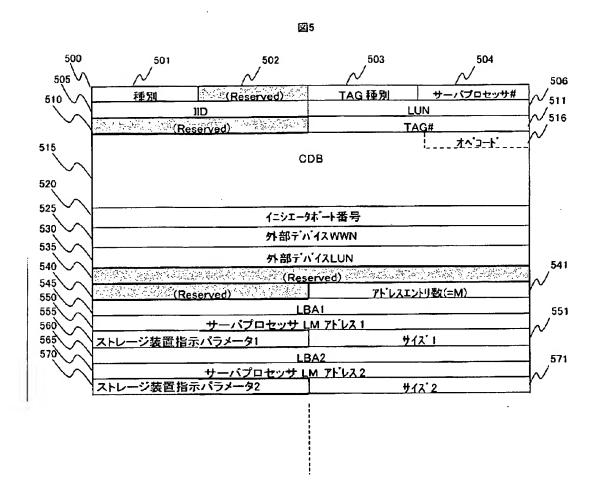
· ...



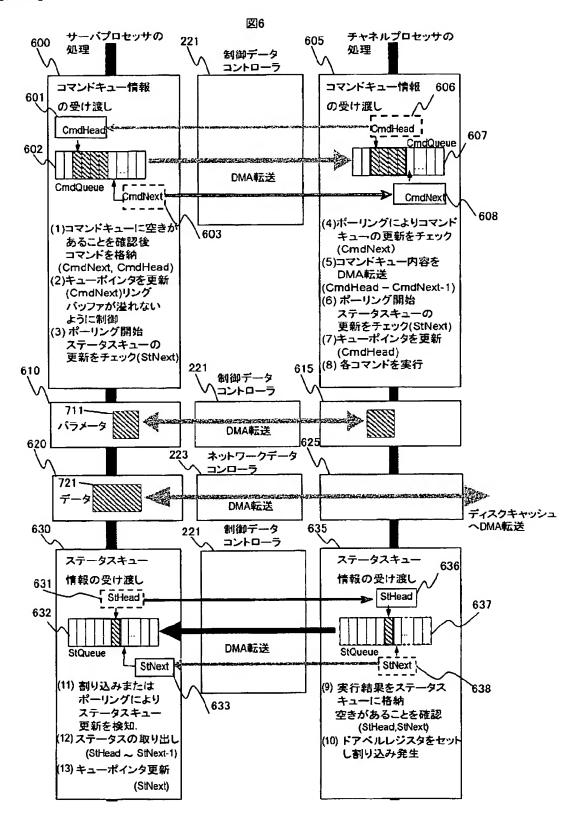
【図4】



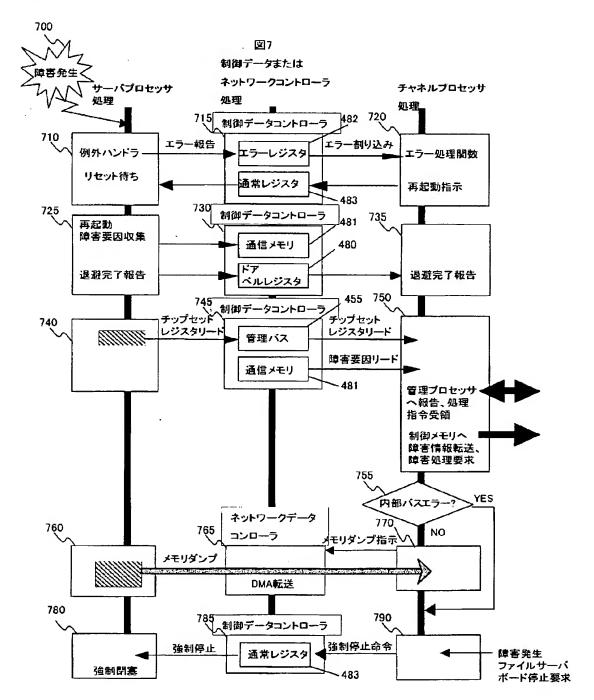
# 【図5】



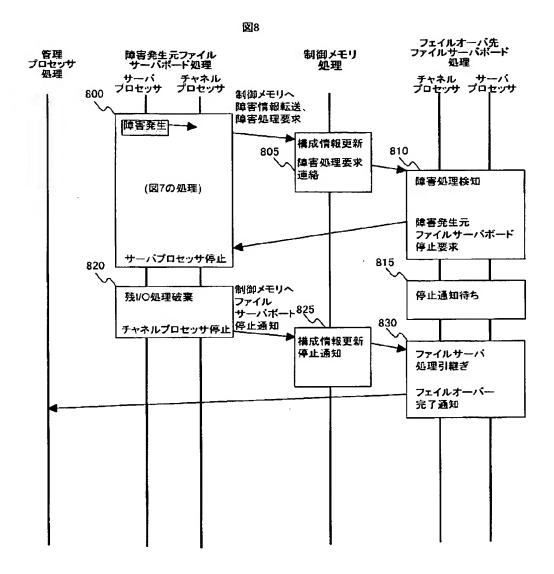
### 【図6】



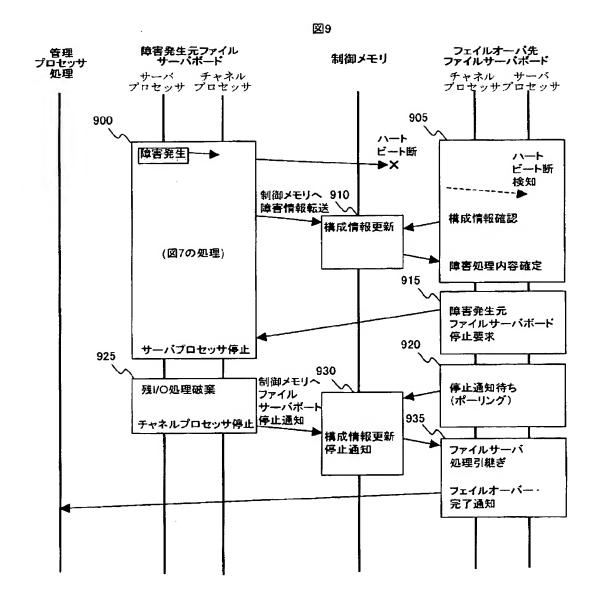
# 【図7】



# 【図8】



# 【図9】



ページ: 1/E

【書類名】

要約書

【要約】

【課題】 ネットワークに直結するストレージシステムにおいて、ファイルサーバで発行された、I/Oコマンドをストレージ装置に送信する際に、従来のI/F及び、プロトコルを用いると、コマンド、データを単一の転送路にてシリアルに転送するために、性能低下が生じる。またアプリケーション、ファイルシステムに固有のI/O特性をストレージ装置に伝達することができない。一方、ファイルサーバのフェイルオーバーを高速かつ正確に行うために、ファイルサーバ側の障害をストレージ装置側で共有する必要もあるが、従来のI/Fではそれを伝える手段がない。

【解決手段】 ファイルサーバとストレージ装置内のチャネルアダプタを同一ボード112上に配置し、その間の接続パスが、複数のプロトコルを独立して稼動できるように制御を行う。またファイルサーバ113とチャネルアダプタ114の間でコマンド、データのパスと独立したパスを置き、受信した障害情報をストレージ装置100内の共有メモリに格納し、フェイルオーバーに用いる。

【選択図】 図1

**)**特願2003-005234

ページ: 1/E

# 認定・付加情報

特許出願の番号

特願2003-005234

受付番号

5 0 3 0 0 0 3 7 7 8 2

書類名

特許願

担当官

第七担当上席 0096

作成日

平成15年 1月15日

<認定情報・付加情報>

【提出日】

平成15年 1月14日

特願2003-005234

出願人履歴情報

識別番号

[000005108]

1. 変更年月日

1990年 8月31日

[変更理由]

新規登録

住所

東京都千代田区神田駿河台4丁目6番地

氏 名

株式会社日立製作所